

基于小波回声状态网络的混沌时间序列预测

宋彤[†] 李菡

(大连理工大学电子信息与电气工程学部, 大连 116023)

(2011 年 7 月 13 日收到; 2011 年 12 月 22 日收到修改稿)

混沌现象普遍存在于自然界及人类社会中, 因此混沌时间序列预测具有重要意义. 提出了一种新的混沌时间序列预测模型——小波回声状态网络, 该模型可以有效克服传统回声状态网络模型中普遍存在的病态矩阵问题, 提高了混沌时间序列预测精度. 通过对 Lorenz、含噪声 Lorenz 及间歇式反应釜釜温三个时间序列的预测, 将小波回声状态网络与传统回声状态网络进行了比较. 结果表明, 小波回声状态网络与传统回声状态网络相比, 预测精度提高一倍以上且预测结果更加稳定.

关键词: 小波分解, 回声状态网络, 小波回声状态网络, 混沌时间序列预测

PACS: 05.45.Tp

1 引言

混沌现象是指确定性系统的不规则运动, 混沌时间序列通常是由确定性非线性系统产生的, 宏观上表现为杂乱无序, 微观上则具有无穷嵌套的自相似性. 混沌现象普遍存在于自然界中, 如生物系统、气象系统等, 因此对混沌时间序列的建模和预测具有重要意义^[1,2]. 但是混沌时间序列具有复杂性、伪随机性及初值敏感性, 这使得对混沌时间序列的精确预测变得十分困难.

目前, 混沌时间序列的预测方法主要有全局预测法^[3]、局域预测法^[4]及基于神经网络的预测方法等^[5,6]. 这些方法的理论依据是 Takens 嵌入定理, 该定理通过相空间重构得到混沌系统相对规则的演化轨迹, 然后通过相空间中的回归与逼近实现对混沌时间序列的预测^[7], 但是这类方法的预测精度受到多方面的限制. 第一, 对于很多实际的混沌时间序列(如脑电信号、气象数据和股票指数等), 其延迟时间和嵌入维数并不能准确确定, 相空间重构的准确性限制了时间序列预测的精度; 第二, 对于高维混沌时间序列, 相空间维数较高, 重构后混沌系统相轨迹较为复杂, 学习算法难以准确逼近. 另外, 混沌时间序列的精度还受到预测模型自身缺

陷的限制, 如神经网络的“过拟合”和网络学习经验化等问题.

Jaeger 和 Haas^[8]于 2004 年提出了一种新的混沌时间序列预测模型, 即回声状态网络 (ESN). ESN 是一种新型的大规模递归神经网络, 其通过储备池网络内部稀疏连接使网络具备记忆能力. ESN 由输入信号激发网络“回声信号”, 通过回声信号的线性组合, 实现混沌时间序列预测. 这种新型的设计方案不仅绕开了传统混沌时间序列预测的瓶颈——相空间重构, 同时也把神经网络训练算法从非凸优化的困境中解脱出来^[9]. 在对 Mackey-Glass 混沌时间序列 84 步预测的测试中, 该方法在精度上超出之前混沌时间序列预测方法上千倍. ESN 的出现为混沌时间序列预测研究注入了新的活力, 其在混沌时间序列预测精度上的突破得到了众多研究者的关注^[10–12].

尽管如此, ESN 也存在着自身的缺陷, 在很多情况下 ESN 的状态矩阵会呈现病态, 这会导致输出权值的幅值过大, 进而影响模型的预测精度和泛化能力, 这个问题困扰了包括 Jaeger 在内的许多研究者. 针对这一问题, 文献 [13] 提出通过加入随机噪声的方法克服病态矩阵的影响, 文献 [11] 通过岭回归、奇异值分解等方法克服 ESN 状态矩阵的

[†] E-mail: tsong@dlut.edu.cn

病态问题, 文献 [12] 采用稀疏贝叶斯法求解输出权值来解决该问题. 然而, 这些方法本质上都是通过引入干扰项来降低状态信号自相关矩阵特征值的离散度, 干扰项的引入不仅增加了不相关的信息, 也增加了学习算法的复杂度. 本文基于小波分解理论和 ESN, 提出小波回声状态网络模型 (WESN). WESN 通过小波分解将时间序列分解成高频分量和低频分量, 然后同时输入到 ESN. 这种设计策略的初衷有以下两点: 第一, 通过将时间序列分解成高频分量和低频分量, 降低问题的学习难度, 提高网络预测精度; 第二, 更为重要的是高频分量可以起到正则化的作用, 进而有效克服传统 ESN 中普遍存在的不适定问题, 并且该方法无需引入额外的干扰项, 因而有望得到更高的预测精度. 本文将通过对 Lorenz 混沌时间序列、含噪声 Lorenz 混沌时间序列以及工业中实际序列的预测验证所提方法的有效性.

2 WESN 及其预测模型

2.1 小波分解

时间序列按正交小波展开的分解算法和重构算法一起称为 Mallat 算法. 该算法类似于快速 Fourier 变换, 是一种纯数字的快速递推算法, 它具有设计简单、运算快捷等特点, 因而得到了广泛的应用. 本文采用 Mallat 小波快速分解算法 [14] 将信号分解为不同频带分量, 从而可以更深入分析信号的特点. 假设 C^J 为需要分解的时间序列信号, 根据分解算法有

$$\begin{aligned} C^j &= LC^{j+1}, \\ D^j &= HC^{j+1}, \end{aligned} \quad (1)$$

其中, L 为低通滤波系数, H 为高通滤波系数, C^j 和 D^j ($j = 0, 1, \dots, J$) 分别为原始信号在分辨率为 $2^{-(j+1)}$ 下的低频分量和高频分量, 即原始信号在两个不同频带上的分量. J 为分解的最大层数, 可将待分解信号 C^J 分解为 $C^{J-1}, C^{J-2}, \dots, C^0$ 和 $D^{J-1}, D^{J-2}, \dots, D^0$.

该分解算法采用逐级二剖分使得每层分解后比分解前的信号数据长度减半, 但是输入数据信号 C^J 的长度与总输出数据信号长度保持一致.

2.2 ESN

ESN 是一种新型的递归神经网络, 其核心是一个大规模、随机生成及稀疏连接的储备池网络, 如图 1 所示. 该网络中输入权值、内部连接权值和输出反馈权值都是随机生成的, 且一经生成就不再改变, 在储备池网络的训练过程中只需要调整输出权值即可. ESN 的基本思想是首先通过输入信号激励储备池网络的状态响应信号, 然后由各个状态响应信号的线性组合逼近期望输出信号 [15].




图 1 ESN 工作原理示意图

ESN 状态演化方程为

$$\begin{aligned} \mathbf{x}(k+1) &= \tanh[\mathbf{W}\mathbf{x}(k) \\ &+ \mathbf{W}_{in}\mathbf{u}(k) + \mathbf{W}_{back}\mathbf{y}(k)], \end{aligned} \quad (2)$$

其中, $\tanh(\cdot)$ 为储备池内部神经元的激活函数, $\mathbf{u}(k)$ 为输入激励信号, $\mathbf{x}(k)$ 为 ESN 的状态向量, $\mathbf{y}(k)$ 为期望输出信号, $\mathbf{W}_{in}$, $\mathbf{W}$ 和 $\mathbf{W}_{back}$ 分别为输入连接权值矩阵、内部连接权值矩阵和输出反馈权值矩阵. ESN 用于时间序列预测时, 通常不需要输出反馈, 即 $\mathbf{W}_{back} = 0$.

ESN 的输出表达式为

$$\mathbf{y}(k+1) = g\{\mathbf{W}_{out}[\mathbf{x}(k+1), \mathbf{u}(k+1)]\}, \quad (3)$$

其中 $g(\cdot)$ 为输出函数. $g(\cdot)$ 通常取恒等函数或符号函数, 当取恒等函数时, 输出权值 $\mathbf{W}_{out}$ 可通过状态矩阵的伪逆求解, 即

$$\mathbf{W}_{out} \approx \mathbf{A}^\dagger \mathbf{Y}, \quad (4)$$

其中 $\mathbf{A} = \{\mathbf{x}(n+1), \mathbf{x}(n+2), \dots, \mathbf{x}(m)\}$ 为状态矩阵, $\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(n)$ 为舍弃的一段初始状态向量.

ESN 在学习过程中常常存在不适定问题 (ill-posed problem), 不适定问题是指状态矩阵 $\mathbf{A}$ 的特征值幅值过高或特征值分散度较大. 当状态矩阵 $\mathbf{A}$ 出现不适定问题时, 输出权值 $\mathbf{W}_{out}$ 的幅值往往过大, 进而影响网络的泛化能力和时间序列的预

测精度.

2.3 WESN 预测模型

结合小波分解理论和 ESN, 本文提出了 WESN, 其工作原理如图 2 所示. WESN 基本思想是通过小

波分解将时间序列分解成低频分量和高频分量, 其中低频分量可以很好地反映时间序列的趋势信息, 而高频分量可以有效克服传统 ESN 模型中存在的病态矩阵问题. 将低频和高频两个分量同时作为输入信号激发 ESN 的状态响应信号, 并通过各个状态响应信号间的线性组合逼近期望输出.




图 2 WESN 工作原理示意图

WESN 的状态演化方程为

$$\mathbf{x}(k+1) = f[\mathbf{W}_{in1}\mathbf{d}_{10}(k) + \mathbf{W}_{in2}\mathbf{d}_{11}(k) + \mathbf{W}\mathbf{x}(k) + \mathbf{W}_{back}\mathbf{y}(k)], \quad (5)$$

其中, $\mathbf{W}_{in1}$ 和 $\mathbf{W}_{in2}$ 分别为输入信号分量 $\mathbf{d}_{10}$ 和 $\mathbf{d}_{11}$ 的输入连接权值矩阵, $\mathbf{d}_{10}(k)$ 和 $\mathbf{d}_{11}(k)$ 分别为原始信号 $\mathbf{u}$ 经小波分解后的低频分量和高频分量.

Jaeger^[15] 指出, 采用噪声抖动 (noise wobble) 方法可显著减小状态矩阵 $\mathbf{A}$ 的特征值分散度, 从而在一定程度上缓解了不适定问题. 噪声抖动技术被认为是克服 ESN 不适定问题的主要途径, 该方法是在向储备池的方程中加入噪声项 $\mathbf{v}(k)$, 即^[15]

$$\mathbf{x}(k+1) = f[\mathbf{W}\mathbf{x}(k) + \mathbf{W}_{in}\mathbf{u}(k) + \mathbf{v}(k) + \mathbf{W}_{back}\mathbf{y}(k)]. \quad (6)$$

通常情况下, 随机噪声 $\mathbf{v}$ 服从高斯分布.

噪声抖动可以在一定程度上克服储备池的不适定问题, 改善 ESN 的性能, 该方法可以看成是一种经验正则化方法. 但是随机噪声 $\mathbf{v}$ 是根据经验人为添加的, 与时间序列自身的信息无关, 因此 $\mathbf{v}$ 的引入在一定程度上增加了干扰信息.

比较 WESN 的状态演化公式 (5) 和噪声抖动公式 (6) 可以发现, 经小波分解后的 (5) 式中的低频分量 $\mathbf{d}_{10}$ 相当于 (6) 式中的输入信号 $\mathbf{u}$, (5) 式中的高频分量 $\mathbf{d}_{11}$ 相当于 (6) 式中的扰动项 $\mathbf{v}$. 由于 $\mathbf{d}_{10}$ 能够更好地反映原始混沌时间序列的变化

趋势, 而 $\mathbf{d}_{11}$ 则可以起到扰动项的作用, 且 $\mathbf{d}_{11}$ 是时间序列自身信息的组成部分, 因此 WESN 无需添加额外的随机噪声就可以很好地克服传统 ESN 训练过程中的不适定问题, 进而可有效提高时间序列的预测精度.

与传统递归神经网络相比, ESN 的输入权值 $\mathbf{W}_{in}$ 和内部连接权值 $\mathbf{W}$ 都是根据特定参数随机生成的, 并且一经生成就固定不变, 在训练过程中仅仅需要调整输出权值. 因此, 网络的动力学性质、稳定性及存储能力都是由储备池参数决定的, 并且在训练过程中不再改变. 生成储备池网络的主要参数有储备池状态维数 N 、输入缩放系数 $\mathbf{S}_{in}$ 、内部连接权值的稀疏度 c 及谱半径 r 等. 其中储备池状态维数 N 决定了储备池的规模 (储备池网络所包含的神经元的数量), 同时也决定储备池网络的建模能力, 即网络能够拟合的非线性动力学方程的复杂程度. 内部反馈连接的存在使得储备池网络具有暂态记忆功能, 其存储能力同样是由储备池状态维数 N 决定的^[15]. 输入缩放系数 $\mathbf{S}_{in}$ 与储备池网络的非线性程度相关, 当 $\mathbf{S}_{in}$ 幅值较大时, 储备池网络非线性程度增加, 而当 $\mathbf{S}_{in}$ 幅值较小时, 储备池网络更接近线性系统. 内部连接权值的稀疏度 c 是指内部连接权值矩阵 $\mathbf{W}$ 的稀疏程度 (即 $\mathbf{W}$ 中非零元素的个数为 N^2c). 内部连接权值矩阵的谱半径 r 与脉冲响应信号的衰减速度和网络的稳定性有关, ESN 通过将 r 设为一个小于 1 的数, 保

证网络的稳定性. 在 WESN 中, 储备池网络的生成机理与传统 ESN 方法是一致的, 因此 WESN 的动力学性质、稳定性和存储能力也都是由生成储备池网络的参数决定的, 并且在同等参数下, WESN 与 ESN 的这些性质几乎是一致的.

综上可知, WESN 继承了传统 ESN 的主要优点, 并且克服了传统 ESN 中普遍存在的不稳定问题. 下面给出采用 WESN 模型对混沌时间序列进行预测的基本步骤.

步骤 1 选择储备池网络的状态维数 N , 内部连接权值的稀疏度 c 及谱半径 r 等参数, 并根据这些参数随机生成储备池网络.

步骤 2 选定一段混沌时间序列作为训练样本, 并对其进行小波分解.

步骤 3 将分解得到的低频分量 d_{10} 和高频分量 d_{11} 同时输入储备池, 激发储备池网络的回声响应信号, 根据储备池状态矩阵 A 和目标信号 y 求解输出权值矩阵 W_{out} .

步骤 4 输入新的观测值并通过回声响应信号的线性组合得到预测值.

3 仿真实验

3.1 评价指标

为了评价 WESN 模型的预测性能, 本文将采用均方根误差 E_{RMS} 作为性能指标对 ESN 和 WESN 两种预测模型进行比较. 均方根误差 E_{RMS} 反映了预测值相对于实际观测值的偏离程度, E_{RMS} 定义为

$$E_{RMS} = \left[\frac{1}{M-1} \sum_{i=1}^M (t_i - y_i)^2 \right]^{1/2}, \quad (7)$$

其中, M 为测试时间序列段的长度, t_i 为实际观测值, y_i 为相应的预测值.

3.2 Lorenz 数据仿真实验

Lorenz 系统是一个典型的混沌系统, 对其研究纵贯整个混沌科学的发展, 其系统方程为

$$\begin{aligned} \dot{x} &= a(y - x), \\ \dot{y} &= (r - z)x - y, \\ \dot{z} &= xy - bz, \end{aligned} \quad (8)$$

其中, a, b 和 r 都为常数. 当取 $a = 10, b = 8/3, r = 28, x(0) = 10, y(0) = 1$ 及 $z(0) = 0$ 时, 系统产生混沌. 利用四阶 Runge-Kutta 算法求解 Lorenz 系统的数值解, 取积分时间步长为 0.01 进行 6000 次迭代, 并取 x 轴时间序列 $x(k), k = 1, 2, \dots, 6000$ 进行数值实验. 前 2000 时步用于网络训练, 后 4000 时步用于测试.

Jaeger^[15] 曾指出, c 越小储备池网络的回声响应信号越丰富, 但也有学者认为全连接的储备池网络性能并不亚于稀疏连接的储备池网络. 本文取 $N = 200, r = 0.98$, 为了考察 c 对 WESN 模型预测性能的影响, 令 c 从 0.1 变化到 0.9.

动态储备池网络是根据指定参数随机生成的, 为了考察随机性对 WESN 预测性能的影响, 本文对于每组储备池参数都生成 10 个网络, 并将 10 个网络的预测均方根误差的平均值和标准差作为预测性能的评价标准. 当 $N = 200, c$ 从 0.1 到 0.9 变化时, ESN 和 WESN 对 Lorenz 混沌时间序列预测的均方根误差如图 3 所示.




图 3 ESN 和 WESN 对 Lorenz 混沌时间序列预测的均方根误差 E_{RMS}

由图 3 可知, 对于 Lorenz 混沌时间序列, 无论是 WESN 还是 ESN, 预测均方根误差 E_{RMS} 随 c 变化不明显, 即 c 对 ESN 和 WESN 预测性能的影响不大. 而无论 c 取何值, WESN 的预测性能均要优于 ESN 的预测性能 (90 个 ESN 的 E_{RMS} 的平均值为 0.002853, 而 90 个 WESN 的 E_{RMS} 的平均值为 0.000958, WESN 的预测精度比 ESN 的预测精度提高了二、三倍). 另外, WESN 的预测均方根误差的标准差也低于 ESN, 这说明 WESN 的预测结果受随机性的影响更小.

3.3 含噪声的 Lorenz 数据仿真实验

实际混沌时间序列大都含有噪声, 为了评价 WESN 对含噪声混沌时间序列的预测性能, 本文采用含有 5% 高斯噪声的 Lorenz 混沌时间序列对 ESN 和 WESN 进行比较. 仍然采用 x 轴混沌时间序列 $x(k)$, $k = 1, 2, \dots, 6000$, 并加入 5% 的高斯噪声进行仿真实验, 前 2000 时步用于网络训练, 后 4000 时步用于网络测试. 取 $N = 200$, c 从 0.1 到 0.9 变化, WESN 和 ESN 对含噪声 Lorenz 混沌时间序列预测的均方根误差如图 4 所示.




图4 含噪声 Lorenz 混沌时间序列的均方根误差 E_{RMS}

由图 4 可知, 对于含噪声 Lorenz 混沌时间序列, WESN 的预测精度比传统 ESN 提高了将近两倍 (90 个 ESN 的 E_{RMS} 的平均值为 0.082572, 而 90 个 WESN 的 E_{RMS} 的平均值为 0.044714), 并且 WESN 的预测结果具有较好的稳定性 (WESN 的 E_{RMS} 的标准差较小, 预测结果受随机性影响较小).

上述结果与不含噪声的 Lorenz 混沌时间序列的预测结果相一致, 这说明无论对于含噪声混沌时间序列, 还是对于不含噪声的混沌时间序列, WESN 的预测精度都要比传统 ESN 网络提高一倍以上, 并且预测结果更为稳定.

3.4 间歇式反应釜温度数据仿真

为了测试 WESN 对实际工业数据的预测性能, 本文采用一个间歇式反应釜的釜内温度进行仿真, 对 WESN 和 ESN 的预测性能进行比较.

选取一段包含 6700 个时间点的釜温时间序列, 取其中前 3000 时段用于网络训练, 后 3700 时段用于网络测试. 在训练和测试之前, 对釜温数据进行

了平滑化和归一化处理. 同样取 $N = 200$, c 从 0.1 到 0.9 变化时, ESN 和 WESN 对釜温时间序列预测的均方根误差如图 5 所示.

由图 5 可知, 对于釜温时间序列, 当 c 为 0.2 时, WESN 与 ESN 的预测精度相当. 除此之外, 对于任何 c 值, WESN 的预测精度都要明显优于 ESN (90 个 ESN 的 E_{RMS} 平均值为 0.048436, 而 90 个 WESN 的 E_{RMS} 平均值为 0.026734). 由此可见, WESN 的预测精度比 ESN 提高一倍以上, 这说明 WESN 可以很好地对实际工业时间序列进行预测.




图5 反应釜釜温时间序列的均方根误差 E_{RMS}

对实际工业时间序列的预测结果与 Lorenz 混沌时间序列、含噪声 Lorenz 混沌时间序列的预测结果也相一致, 说明无论对实际工业数据, 还是理论数据, WESN 的预测精度都要比传统 ESN 提高一倍以上, 并且预测结果更加稳定.

为了进一步分析 ESN 和 WESN 对实际工业时间序列的预测性能, 观察 c 为 0.3 时对实际工业时间序列的预测结果, 分别采用 ESN 和 WESN 对釜温时间序列进行预测, 结果如图 6 所示.

由图 6 可知, WESN 和 ESN 对 3001—4950 s 时段的预测都得到了较高的精度. 反应釜釜温时间序列在 4800—5200 s 和 5800—6100 s 时段都是连续上升的, 这导致了 WESN 和 ESN 对 4951—5400 s 和 5900—6300 s 时段的预测都出现了一定程度的偏离. 由于 WESN 模型存在低频分量和高频分量两个输入变量, 高频输入相当于正则化的过程 (如 (5) 式), 因此在 WESN 的预测结果中只出现了较小幅度的偏离, 而在 ESN 的预测结果中出现了较大幅度的偏离, 这说明 WESN 与 ESN 相比具有更好的泛化能力.




图6 反应釜釜温的预测结果 (a) 观测值和 ESN 的预测值; (b) 观测值和 WESN 的预测值

4 结论

本文基于小波分解理论与 ESN 提出了一种新的混沌时间序列预测模型——WESN. 该模型首先对时间序列进行小波分解, 然后将低频分量和高频分量同时作为储备池网络的输入, 其中高频分量可以起到正则化的作用, 因而 WESN 能够有效克服传统 ESN 模型中存在的过拟合问题, 并且与传统方法相比无需引入额外的干扰信号. 另外, WESN 将

能够反映时间序列变化趋势的低频分量分离出来, 可以有效降低预测时的学习复杂度, 提高预测精度. 在对 Lorenz 混沌时间序列、含噪声 Lorenz 混沌时间序列及反应釜釜温时间序列的预测中, WESN 模型与传统的 ESN 模型相比, 预测精度均提高一倍以上, 并且表现出较好的平稳性和泛化性. 通过对这三个时间序列的预测, 说明了 WESN 在混沌时间序列预测中的有效性.

- [1] Wang Y S, Sun J, Wang C J, Fan H D 2008 *Acta Phys. Sin.* **57** 6120 (in Chinese) [王永生, 孙瑾, 王昌金, 范洪达 2008 物理学报 **57** 6120]
- [2] Ma M, Li S 2010 *Commer. Res.* **403** 10 (in Chinese) [马明, 李松 2010 商业研究 **403** 10]
- [3] Meng Q F, Peng Y H, Qu H J, Han M 2008 *Acta Phys. Sin.* **57** 1423 (in Chinese) [孟庆芳, 彭玉华, 曲怀敬, 韩民 2008 物理学报 **57** 1423]
- [4] Li J, Liu J H 2005 *Acta Phys. Sin.* **54** 4569 (in Chinese) [李军, 刘君华 2005 物理学报 **54** 4569]
- [5] Ma Q L, Zhen Q L, Peng H, Qin J W 2009 *Acta Phys. Sin.* **58** 1410 (in Chinese) [马千里, 郑启伦, 彭宏, 覃姜维 2009 物理学报 **58** 1410]
- [6] Yan H, Wei P, Xiao X C 2007 *Acta Phys. Sin.* **56** 5111 (in Chinese) [闫华, 魏平, 肖先赐 2007 物理学报 **56** 5111]
- [7] Takens F 1981 *Lecture Notes in Mathematics* (Berlin: Springer-Verlag) pp366—381
- [8] Jaeger H, Haas H 2004 *Science* **304** 78
- [9] Lukoševičius M, Jaeger H 2009 *Comput. Sci. Rev.* **3** 127
- [10] Song Q S, Feng Z R, Li R H 2009 *Acta Phys. Sin.* **58** 5057 (in Chinese) [宋青松, 冯祖仁, 李人厚 2009 物理学报 **58** 5057]
- [11] Shi Z W, Han M 2007 *Control Decis.* **22** 258 (in Chinese) [史志伟, 韩敏 2007 控制与决策 **22** 258]
- [12] Han M, Mu D Y 2010 *Control Decis.* **25** 531 (in Chinese) [韩敏, 穆大芸 2010 控制与决策 **25** 531]
- [13] Jaeger H 2005 *Proceedings of the International Joint Conference on Neural Networks* (Montreal: IEEE) p1460
- [14] Xu C F, Li G K 2001 *Practical Wavelet Method* (Wuhan: Huazhong University of Science Press) pp75—78 (in Chinese) [徐长发, 李国宽 2001 实用小波方法 (武汉: 华中科技大学出版社) 第 75—78 页]
- [15] Jaeger H 2007 *Scholarpedia* **2** 2330

Chaotic time series prediction based on wavelet echo state network

Song Tong[†] Li Han

(*Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116023, China*)

(Received 13 July 2011; revised manuscript received 22 December 2011)

Abstract

Chaos is widespread in nature and human society, so the prediction of chaotic time series is very important. In this paper, we propose a new chaotic time series prediction model — echo state network based on wavelet, which can effectively overcome the ill-posed problem that exists in traditional echo state networks. And it also has a good generalization ability. Three time series are used to test the new model, i.e., Lorenz time series, Lorenz time series with added noise and Batch reactor vessel temperature time series. Results suggest that the new proposed method can achieve a higher predictable accuracy, better generalization and more stable prediction results than traditional echo state networks.

Keywords: wavelet decomposition, echo state networks, echo state networks based on wavelet, chaotic time series prediction

PACS: 05.45.Tp

[†] E-mail: tsong@dlut.edu.cn